

BAB II

TINJAUAN PUSTAKA

2.1 *Demand Forecasting*

Awal teori *forecasting* ini dikembangkan berdasarkan dari premis bahwa data yang ada pada saat ini dan masa lalu dapat digunakan untuk memprediksi masa depan (Christofer, 2021; Febrian et al., 2020; Idrees et al., 2019; Petropoulos et al., 2022). Implementasi *forecasting* akan memberikan hasil yang optimal ketika digunakan untuk menganalisis dan memberikan solusi pada permasalahan yang berkaitan dengan praktik (Petropoulos et al., 2022). Dengan begitu, hasil metode *forecasting* akan mengarahkan perusahaan untuk memiliki praktik yang lebih baik.

Pada sistem *supply chain* perusahaan, metode *forecasting* juga sangat penting untuk diterapkan. Dalam hal ini, *forecasting* menjadi salah satu input dasar dalam pengambilan keputusan karena memberikan informasi terkait perkiraan permintaan di masa yang akan datang (Christofer, 2021). Hal ini penting untuk diterapkan dalam operasional karena membantu untuk menyeimbangkan *supply* dan *demand*. Heizer et al., (2023) juga menyatakan bahwa melalui *forecasting* dapat menjadi kunci penting dalam menerapkan layanan dan operasional manufaktur dengan efisien. Hasil *forecasting* akan memberikan informasi yang mendalam terkait perencanaan produksi, sumber daya manusia, pengelolaan inventaris, manajemen arus kas, dan logistik perusahaan (Petropoulos et al., 2022).

Menurut Heizer et al., (2023) *forecasting* dibagi menjadi 3 kategori dalam perencanaan operasionalnya yaitu:

1. *Economic forecasts*

Dalam *forecasting* ini akan membantu perusahaan mendapatkan informasi untuk jangka menengah dan jangka panjang. Dalam hal ini *forecasting* akan berkaitan dengan prediksi inflasi, tingkat pembangunan rumah, jumlah uang beredar, dan indikator perencanaan lainnya.

2. *Technological forecasts*

Forecasting ini akan berguna untuk mengukur tingkat kemajuan teknologi di masa yang akan datang. Melalui *forecasting* ini memunculkan peluang akan lahirnya teknologi baru. Dengan hal ini nantinya dibutuhkan fasilitas dan peralatan yang baru.

3. *Demand forecasts*

Dalam kategori ini *forecasting* digunakan perusahaan untuk memprediksi tingkat permintaan produk dan/atau jasa di masa yang akan datang. Dengan *forecasting* akan membantu manajemen puncak melakukan keputusan. Hal ini akan membutuhkan informasi yang cepat dan akurat dari data permintaan yang sebenarnya. Dengan adanya *demand forecasting* ini akan membantu perusahaan dalam mendorong proses produksi, sistem penjadwalan, dan kapasitas perusahaan. Selain itu, hasil *forecasting* menjadi salah satu

input dalam perancangan keuangan, sumber daya, dan pemasaran.

Demand forecasting akan berpengaruh besar dalam meminimalisir inventaris dan kerusakan.

Dalam penelitian ini metode *forecasting* yang digunakan adalah *traditional time series forecasting*. Pengertian dari *time series* adalah analisis yang dilakukan dengan data historis dari waktu ke waktu untuk membuat *forecasting* (Febrian et al., 2020; Shah dan Thaker, 2024). Peran *time series forecasting* sangat penting dalam berbagai bidang didasarkan pada prediksi yang tepat di masa depan menjadi hal yang krusial.

2.2 Double Moving Average

Salah satu metode *demand forecasting* yang digunakan dalam penelitian ini adalah *Moving Average*. Metode *Moving Average* adalah suatu proses untuk memprediksi periode yang akan datang menggunakan data yang sudah dikumpulkan melalui observasi dengan mencari rata-rata pada periode saat ini dan masa lalu (Shawafira Nasha et al., 2024). Heizer et al., (2023) menambahkan bahwa metode *Moving Average* adalah prediksi yang menggunakan sejumlah nilai dari data historis yang aktual. Pernyataan ini sejalan dengan penelitian Khairina et al., (2020) bahwa *Moving Average* merupakan metode yang menggunakan data permintaan aktual untuk menghasilkan prediksi permintaan pada periode berikutnya. Metode ini

memiliki dua kategori yaitu *Single Moving Average* dan *Double Moving Average*.

Pada penelitian ini akan berfokus untuk melakukan penghitungan dengan metode *Double Moving Average*. Penghitungan *Double Moving Average* berdasarkan dari hasil data *Single Moving Average*. Lebih jelasnya penghitungan metode ini dilakukan dalam 2 tahap yaitu penghitungan prediksi awal dan penghitungan kembali dengan hasil penurunannya untuk mendapatkan hasil prediksi yang baru (Shawafira Nasha et al., 2024). Rumus dalam metode *Double Moving Average* akan dijelaskan sebagai berikut:

$$S'_t = \frac{X_t + X_{t-1} + \dots + X_{(t+1)-n}}{n}$$

$$S''_t = \frac{S'_t + S'_{t-1} + \dots + S'_{(t+1)-n}}{n}$$

$$a_t = 2 S'_t - S''_t$$

$$b_t = \frac{2}{n-1} (S'_t - S''_t)$$

$$F_t = a_t + b_t m$$

Dimana:

S'_t = *Moving Average* pertama

S''_t = *Moving Average* kedua

X_t = nilai aktual deret waktu

α = parameter pemulusan

a_t = konstanta

b_t = koefisien tren

F_{t+m} = hasil *forecasting* untuk periode yang akan datang

2.3 Double Exponential Smoothing

Exponential Smoothing adalah metode pemulusan data dengan runtun waktu dengan memberikan bobot secara menurun pada observasi terbaru hingga observasi terlama (Christofer, 2021). Pada *Double Exponential Smoothing* memiliki dua jenis metode yang dikembangkan oleh Holt dan metode oleh Brown. Pada penelitian ini akan berfokus pada *Brown's Double Exponential Smoothing*.

Berdasarkan penelitian yang dilakukan oleh Febrian et al., (2020) bahwa metode yang diciptakan oleh Brown ditujukan agar dapat menangani perbedaan antara data aktual dengan hasil *forecasting* yang dikarenakan munculnya tren pada plot data. Khusnul Khotimah et al., (2024) juga mengemukakan bahwa implementasi metode *Double Exponential Smoothing* didasarkan pada data yang memiliki pola tren. Dalam penelitian Christofer (2021) menjelaskan metode *Exponential Smoothing* ini dibagi menjadi 3 kategori sebagai berikut:

1. *Simple Exponential Smoothing*

Metode ini juga biasa disebut dengan *Single Exponential Smoothing* yang banyak digunakan dalam bisnis untuk memprediksi permintaan dalam jangka waktu pendek. Aplikasi metode ini dengan mengasumsikan bahwa data yang digunakan berfluktuasi di sekitar rata-rata yang tetap, data yang tanpa tren, dan memiliki

pertumbuhan relatif konsisten. Penghitungan metode ini akan memberikan penekanan yang besar pada *time series* dengan menggunakan parameter pemulusan.

2. *Double Exponential Smoothing*

Metode ini lebih efektif digunakan untuk mencari data yang memiliki pola tren. Ada dua cara mengaplikasikan metode ini yaitu dengan teori yang dikembangkan oleh Brown's dan oleh Holt. Pada penelitian ini menggunakan metode *Double Exponential Smoothing* yang dikembangkan oleh Brown dengan persamaan sebagai berikut:

$$S'_t = \alpha X_t + (1 - \alpha) S'_{t-1}$$

$$S''_t = \alpha S'_t + (1 - \alpha) S''_{t-1}$$

$$a_t = 2 S'_t - S''_t$$

$$b_t = \frac{\alpha}{(1 - \alpha)} (S'_t - S''_t)$$

$$F_t = a_t + b_t m$$

Dimana:

S'_t = pemulusan *exponential* pertama

S''_t = pemulusan *exponential* kedua

X_t = nilai aktual deret waktu

α = parameter pemulusan

a_t = konstanta

b_t = koefisien tren

F_{t+m} =hasil *forecasting* untuk periode yang akan datang

3. *Triple Exponential Smoothing*

Metode ini akan digunakan pada data yang menunjukkan pola tren dan musiman. Data yang memiliki pola musiman ini penting menjadi salah satu komponen untuk menunjukkan variasi pada variabel dependen dalam periode waktu selama 1 tahun.

Tujuan implementasi *Double Exponential Smoothing* untuk memprediksi hasil *forecasting* yang memiliki data fluktuatif (Shawafira Nasha et al., 2024). Metode ini menggunakan parameter pemulusan atau alpha (α) dengan nilai lebih besar dari 0 dan kurang dari 1.

2.4 *Heuristic Aggregate Planning*

Magdalena (2020) mendefinisikan *Aggrerate Planning* sebagai perencanaan yang dilakukan untuk menetapkan permintaan pada setiap elemen produksi di perusahaan serta menentukan jumlah tenaga kerja yang dibutuhkan untuk memenuhi permintaan tersebut. Lebih lanjut, tujuan *Aggregate Planning* yaitu untuk merancang tingkat output dengan biaya rendah yang memenuhi permintaan agar mendapatkan keuntungan yang maksimal (Anindita dan Yotenka, 2024). Menurut Heizer et al., (2023) bahwa *Aggrerate Planning* adalah perencanaan mencakup *forecasting* yang berkaitan dengan inventaris, produk jadi, keterbatasan, dan sumber daya manusia. Pengaplikasian *Aggregate Planning* ditujukan untuk mengurangi biaya produksi melalui hasil *forecasting* sebelumnya (Shawafira Nasha et al., 2024). Oleh karena itu, perencanaan

Agregate Planning diintegrasikan dengan hasil *demand forecasting* untuk menentukan perencanaan produksi yang efisien.

Hasil *Aggregate Planning* adalah prediksi permintaan pada periode selanjutnya serta menganalisis tingkat produksi, tingkat tenaga kerja, waktu kerja lembur, tingkat persediaan, subkontrak, dan variabel lain yang dapat dikontrol (Heizer et al., 2023). Tujuan utama dalam menerapkan *Aggregate Planning* adalah untuk memenuhi permintaan yang ada dengan biaya yang lebih efisien selama perancangan produksi.

Lebih jelasnya dalam penelitian ini akan menggunakan *Heuristic Aggregate Planning*. Pendekatan *heuristic* termasuk dalam metode kuantitatif yang dapat menyelesaikan masalah dengan memberikan jawaban secara rasional dan cepat (Ridha, 2015). Penelitian oleh Segovia-Aguas et al., (2021) menyatakan bahwa pendekatan *heuristic* menjadi salah satu metode yang paling sukses dalam menetapkan perencanaan klasik. Dijelaskan lebih rinci oleh Ridha (2015) bahwa metode *heuristic* dapat memberikan hasil yang maksimal salah satunya dalam bidang perencanaan produksi.

Menurut Heizer et al., (2023) bahwa keberhasilan *Heuristic Aggregate Planning* berdasarkan pada perbandingan permintan yang telah diprediksi dengan kapasitas yang sudah ada. Dalam menerapkan *Heuristic Aggregate Planning* dapat dilakukan lima tahapan sebagai berikut:

1. Menetapkan permintaan pada setiap periode.

2. Menentukan kapasitas pada setiap waktu kerja regular, lembur, dan subkontrak pada setiap periode.
3. Menetapkan biaya tenaga kerja, biaya perekrutan, biaya pengurangan tenaga kerja, dan biaya persediaan.
4. Mempertimbangkan kebijakan perusahaan agar dapat diimplementasikan pada pekerja dan persediaan.
5. Mengembangkan perancangan alternatif dan total biaya.

Dalam penelitian ini akan berfokus untuk meninjau *Workforce Control Strategy* dan *Overtime Control Strategy*. Dalam *Workforce Control Strategy* metode akan digunakan ketika tingkat produksi dapat sesuai dengan tingkat permintaan setiap bulannya (Shawafira Nasha et al., 2024). Dengan adanya strategi ini dapat mempengaruhi tingkat produksi sehingga outputnya dapat mengikuti permintaan dan menjaga persediaan agar tetap stabil. Hal ini dilakukan dengan meninjau jumlah tenaga kerja ketika tingkat produksi rendah dilakukan penambahan tenaga kerja dan sebaliknya ketika tingkat produksi terlalu tinggi maka dilakukan pengurangan tenaga kerja (Magdalena, 2020).


Overtime Control Strategy akan mengikuti hasil dari pengendalian tenaga kerja (Shawafira Nasha et al., 2024). Ketika permintaan melebihi kemampuan produksi, maka dilakukan penambahan jam kerja atau lembur untuk dapat memenuhi permintaan tersebut. Kedua strategi ini diterapkan agar kegiatan produksi dapat berjalan secara efektif dan pengelolaan komposisi tenaga kerja produksi yang sesuai dengan permintaan.

2.5 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah suatu metrik pada model regresi untuk mengukur persentase kesalahan yang lebih peka pada pilihan dengan variasi relatif yang memiliki dampak lebih besar daripada variasi absolut (Chicco et al., 2021). Menurut penelitian Mutia et al., (2024) bahwa definisi MAPE adalah pengukuran presentase kesalahan dari hasil *demand forecasting* dengan data permintaan aktualnya ditunjukkan dengan nilai rata-rata deviasi absolut.

Implementasi MAPE banyak digunakan dalam praktik karena hasilnya yang sangat intuitif pada kesalahan variasi relatif (De Myttenaere et al., 2016). Penghitungan nilai MAPE dilakukan dengan nilai rata-rata kesalahan absolut pada periode yang diteliti lalu mengalikan hasil tersebut dengan 100% (Shawafira Nasha et al., 2024). Hasil yang diperoleh ini nantinya menjadi ukuran variabel apakah hasil *demand forecasting* menunjukkan ketepatan.

2.6 Diagram Alir Penelitian



Gambar 2. 1 Diagram Alir Penelitian

Langkah kerja pertama yang dilakukan dalam penelitian adalah mengidentifikasi masalah pada Cheesecake Stori. Berdasarkan hasil

wawancara yang dilakukan tersebut diketahui bahwa permasalahan utama adalah minimnya kemampuan untuk memprediksi penjualan produk yang mempengaruhi ketersediaan produk yang ada. Permasalahan ini sangat berkaitan dengan perencanaan produksi dan menentukan jumlah permintaan. Oleh karena itu, pada penelitian ini dilakukan analisis menggunakan dua metode *demand forecasting* yaitu *Double Moving Average* dan *Double Exponential Smoothing*. Setelah hasil *demand forecasting* didapatkan lalu digunakan untuk membuat perancangan produksi menggunakan *Heuristic Aggregate Planning*.

2.7 Penelitian Terdahulu

Tabel 2. 1
Penelitian Terdahulu

No.	Nama Peneliti	Judul dan Tahun Penelitian	Metodologi	Hasil Penelitian
1.	Kayla Shawafira Nasha, Syarif Hidayat, dan Nunung Nurhasanah	Planning Daily Bread Production Using Forecasting Method and Heuristic Aggregate Method on CV. Delia Bakery (2024)	Metode pengumpulan data pada penelitian ini melalui wawancara dan data internal perusahaan. Data internal yang digunakan adalah data penjualan pada bulan Mei dan Juni tahun 2023 sebanyak 53 periode.. Produksi roti dilakukan berdasarkan permintaan penjual tanpa target yang jelas. Hal ini mengakibatkan produksi yang tidak efisien dan keuntungan yang belum maksimal. Untuk mengatasi masalah ini, digunakan dua metode <i>forecasting</i> yaitu <i>Double Moving Average</i> dan <i>Double</i>	Melalui metode Double Exponential Smoothing (DES) dengan $\alpha=0.1$ mendapatkan hasil MAPE terendah sebesar 9,91%. Hasil untuk periode ke-54 sebanyak 9510 pcs, periode ke-55 sebanyak 9502 pcs, periode ke-56 sebanyak 9494 pcs, periode ke-57 sebanyak 9486 pcs, periode ke-58 9478, dan terakhir periode ke-59 sebanyak 9470.

No.	Nama Peneliti	Judul dan Tahun Penelitian	Metodologi	Hasil Penelitian
			<i>Exponential Smoothing</i> (DES) untuk memprediksi kebutuhan produksi yang sesuai dengan permintaan. Setelah hasil <i>forecasting</i> didapatkan, hasil tersebut digunakan untuk merencanakan produksi dengan metode <i>Aggregate Planning</i> .	
2.	Didi Febrian, Said Iskandar Al Idrus, dan Debora Agnes Jessica Nainggolan	<i>The Comparison of Double Moving Average and Double Exponential Smoothing Methods in Forecasting the Number of Foreign Tourists Coming to North Sumatera</i> (2020)	Penelitian ini meneliti wisatawan mancanegara yang akan ke Sumatera Utara. Metode yang digunakan dalam penelitian ini adalah <i>Double Moving Average</i> (DMA), <i>Double Exponential Smoothing</i> (DES) <i>Brown's Method</i> , dan <i>Double Exponential Smoothing</i> (DES) <i>Holt's Method</i> . Sumber data dalam penelitian adalah data sekunder yang didapatkan dari data BPS dengan total 108 data diambil dari Januari 2010 hingga Desember 2018.	Melalui hasil penelitian menunjukkan bahwa penghitungan dengan metode DMA mendapatkan tingkat MAPE sebesar 14,12%, DES Brown sebesar 12,71%, dan DES Holt sebesar 12,21%. Berdasarkan hasil tersebut, peramalan selanjutnya akan menggunakan <i>Double Exponential Smoothing Holt's Method</i> .
3.	Nurhastuti Ika Dewi dan Lilia Pasca Riani	<i>Analisis Forecasting Demand terhadap Penjualan Roti Tawar (Studi Kasus di Toko Roti Smart Bakery)</i> (2024)	Jenis penelitian ini adalah deskriptif dengan pendekatan kuantitatif. Metode pengumpulan data yang digunakan adalah data primer melalui wawancara dengan karyawan Smart Bakery dan data sekunder melalui data penjualan pada bulan Mei 2023 sampai Mei 2024. Metode <i>forecasting</i> yang digunakan adalah Pembobotan Rata-rata Bergerak, Rata-Rata Bergerak, Pendekatan Naif,	Hasil penelitian ini dari metode yang memiliki MAPE terendah yaitu metode Penghalusan Eksponensial tunggal memiliki MAPE sebesar 17,08%; metode Rata-rata Bergerak memiliki MAPE sebesar 25,37%, metode Pendekatan Naif memiliki MAPE sebesar 25,37%; metode Pembobotan Rata-Rata Bergerak memiliki MAPE sebesar 26,12%; metode Penghalusan Eksponensial linear memiliki MAPE sebesar

No.	Nama Peneliti	Judul dan Tahun Penelitian	Metodologi	Hasil Penelitian
			Monte carlo, <i>Single Exponential Smoothing</i> (SES) dengan konstanta α 0,1 / β 0,5, dan <i>Linear Exponential Smoothing</i> (LES) dengan konstanta α 0,1 / β 0,3.	27,20%; dan metode Monte Carlo memiliki MAPE sebesar 29,33%.

